2000 November 2

(Item 1 from file: 347)

DIALOG(R) File 347: JAPIO

(c) 2000 JPO & JAPIO. All rts. reserv.

Image available 04764308

DOCUMENT PROCESSOR

07-056908 JP 7056908 PUB. NO.: March 03, 1995 (19950303) PUBLISHED:

INVENTOR(s): MURATA MAKOTO

APPLICANT(s): FUJI XEROX CO LTD [359761] (A Japanese Company or

Corporation), JP (Japan)

05-218142 [JP 93218142] August 09, 1993 (19930809) APPL. NO.: FILED:

[6] G06F-017/21; G06F-017/27; G06F-017/30 INTL CLASS:

JAPIO CLASS: 45.4 (INFORMATION PROCESSING -- Computer Applications)

ABSTRACT

PURPOSE: To provide a document processor which can efficiently match structure patterns.

CONSTITUTION: A logical structure holding part 1 holds the logical structure of a document. A template holding part 2 holds the template of the document. The logical structure of the document held in the logical structure holding part 1 has structure based on the template held in the template holding part 2. A structure pattern holding part 3 holds the structure pattern which is matched. A structure pattern matching processing part 4 restricts a range where a retrieval processing is executed among the logical structures of the document, which are held in the logical structure holding part 1, based on the template of the document, which is held in the template holding part 2, and the structure pattern held in the structure pattern holding part 3. A part fitted to the structure pattern is retrieved within the restricted range and among the logical structures of the document.

(19)日本国特許庁(JP)

(12) 公開特許公報(A)

(11)特許出願公開番号

特開平7-56908

(43)公開日 平成7年(1995)3月3日

(51) Int.CL®

酸別記号

庁内整理番号

FΙ

技術表示箇所

G06F 17/21

17/27 17/30

7315-5L

G 0 6 F 15/20

590 E

7315-5L

550 E

審査請求 未請求 請求項の数1 FD (全 5 頁) 最終頁に続く

(21)出願番号

(22)出願日

特願平5-218142

平成5年(1993)8月9日

(71)出願人 000005496

富士ゼロックス株式会社

東京都港区赤坂三丁目3番5号

(72)発明者 村田 真

神奈川県横浜市保上ケ谷区神戸町134番地

横浜ビジネスパークイーストタワー 富

1:ゼロックス株式会社内

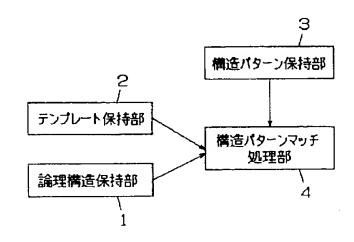
(74)代理人 弁理士 石井 康夫 (外1名)

(54) 【発明の名称】 文書処理装置

(57)【要約】

【目的】 効率よく構造パターンマッチを行なうことのできる文書処理装置を提供する。

【構成】 論理構造保持部1は、文書の論理構造を保持する。テンプレート保持部2は、文書のテンプレートを保持する。論理構造保持部1に保持されている文書の配理構造は、テンプレート保持部2に保持されている。構造パターンを存むう構造パターンマッチを行なう構造パターンを保持している。構造パターンマッチを理部4は、テンプレート保持部2に保持されている文書のテンプレートと、構造パターン保持部3に保持されている構造パターンに基づいて、論理構造保持されている構造のうちから、構造パターンに適合する部分を探索する。



1

【特許請求の範囲】

【請求項1】 構造化文書の検索、自動生成を行なう文書処理装置において、文書の論理構造のテンプレートを保持するテンプレート保持部と、文書の論理構造を保持する論理構造保持部と、構造パターンを保持する構造の方も、構造保持部に保持されている構造パターンに適合している部分を探索も関連を行なう構造パターンでッチ処理部を有し、該部造パターンマッチ処理部は、前記テンプレート保持に保持されるテンプレートを利用して探索処理を領に保持されるテンプレートを利用して探索処理を行なうことを特徴とする文書処理装置。

【発明の詳細な説明】

[0001]

【産業上の利用分野】本発明は、構造化文書の検索、自動生成を行なう文書処理装置に関するものである。

[0002]

【従来の技術】構造化文書を扱う文書処理装置において、文書の効率的な作成を支援するため、複数の文書を合成するなど、プログラムによって、新たな構造化文書を自動生成する文書自動生成処理や、図などの構造化文書の部品を検索し、部品単位での再利用を行なう文書的最大でなえる。このような文書自動生成処理や文書部品検索処理では、構造パターンマッチが有効である。ここで、構造パターンマッチとは、指定の中から探すことをいう。文書自動生成処理では、文書部品を、文書では、文書の検索を構造パターンによって指示する。文書部品検索では、文書部品検索を構造パターンによって指示する。

【0003】構造パターンとは、「文書論理構造中の部品に対する条件」と、「部品の接続関係にある条件」を組合わせたものである。例えば、「図表見出しに文字列『インストール』が表れる図』は、構造パターンの1例である。文書部品Aがこの構造パターンに適合するのは、

- 1. 文書部品Aは図である。
- 2. ある文書部品Bがあって、

2-1. 文書部品Bは文字列「インストール」を含む図 表見出しである。

2-2. 文書部品Bは文書構造中で、文書部品Aの直下にある。

という条件が成り立つときである。この例では、「文書 論理構造中の部品に対する条件」が1. と2-1. の条 件であり、「部品の接続関係にある条件」が2-2. の 条件である。

【0004】構造バターンマッチを用いている従来の文 書処理システムとしては、例えば、DRAFT INT ERNATIONAL STANDARD ISO/I ECDIS 10179, "Information technology-Text and offic e systems-Document Style Semantics and Specificati on Language (DSSSL) がある。このD SSSLでは、構造パターンマッチのことをロケーショ

2.

【0005】また、情報処理学会第42回(平成3年前期)全国大会、6Q-4、「文書処理統合環境DleTにおける文書データ処理言語」に記載されているDPL

(DleT Processing Language) においても、文書構造のパターンマッチを取り入れている。

【0006】これらの文献においては、構造パターンマッチをいかにして行なうかは示されていない。例えば一つの方法として、文書構造を深さ優先に構造パターンの同じものを探索することにより、文書構造のパターンマッチが行なえることは容易に考えつく。しかし、この方法では、検索に時間がかかるという問題がある。

20 [0007]

ンモデルと呼んでいる。

【発明が解決しようとする課題】本発明は、上述した事情に鑑みてなされたもので、効率よく構造パターンマッチを行なうことのできる文書処理装置を提供することを目的とするものである。

[0008]

【課題を解決するための手段】本発明は、構造化文書の検索、自動生成を行なう文書処理装置において、文書の論理構造のテンプレートを保持するテンプレート保持部と、文書の論理構造を保持する論理構造保持部と、構造パターンを保持する構造パターン保持部に保持されている文書の論理構造のうちから前記構造パターン保持部に保持されている構造パターンに適合している部分を探索する処理を行なう構造パターンマッチ処理部を有し、該構造パターンマッチ処理部を有し、該構造パターンマッチ処理部を有し、該構造パターンマッチ処理部を有し、該構造パターンマッチ処理部を有し、該構造パターンマッチ処理部を有し、該構造パターンマッチ処理部を有し、該構造パターンマッチ処理部を有し、該構造の一部に限定し、限定した範囲内で探索処理を行なうことを特徴とするものである。

[0009]

【作用】論理構造保持部に保持される文書の論理構造は、テンプレート保持部に保持されるテンプレートに従っている。構造パターンマッチ処理部は、構造パターン保持部に保持される構造パターンと、テンプレート保持部に保持されているテンプレートを比較することによって探索の範囲を一部に限定することができる。この限定された探索の範囲内で、論理構造保持部に保持される文書の論理構造に対して構造パターンマッチを行なう。これにより、高速に構造パターンマッチを行なうことができる。

7 [0010]

【実施例】図1は、本発明の文書処理装置の一実施例を 示すブロック図である。図中、1は論理構造保持部、2 はテンプレート保持部、3は構造パターン保持部、4は 構造パターンマッチ処理部である。 論理構造保持部 1 は、文書の論理構造を保持する。テンプレート保持部2 は、文書のテンプレートを保持する。論理構造保持部1 に保持されている文書の論理構造は、テンプレート保持 部2に保持されているテンプレートに基づいた構造を有 している。構造パターン保持部3は、構造パターンマッ チを行なう構造バターンを保持している。構造パターン マッチ処理部4は、論理構造保持部1に保持されている 文書の論理構造のうちから、構造パターン保持部3に保 持されている構造パターンに適合している部分を探索す る。このとき、テンプレート保持部2に保持されている 文書のテンプレートを用いて、文書の論理構造のうちか ち、探索処理を行なう範囲を限定し、限定された範囲内

論理根::=梗概 章+ 文献リスト 付録

梗概::=段落 ··· (B)

で探索処理を行なう。

章::=章見出し 段落+ ··· (C)

··· (D) 文献リスト:ニ文献名+

付録::=図+ ···(E)

ここで、"::="は、右辺の項目の並びによって左辺 が定義されていることを示し、右辺の項目の後ろの '+'は、その項目の1個以上の繰り返しを示してい る。

【0014】論理根は、文書を示す。文書は、式(A) のように定義され、1個の梗概、章の1個以上の繰り返 し、1個の文献リスト、1個の付録から構成されてい る。梗慨は、式 (B) のように定義され、1個の段落か ら構成されている。章は、式 (C) のように定義され、 1個の章見出しと、段落の1個以上の繰り返しから構成 されている。文献リストは、式 (D) のように定義さ れ、文献名の1個以上の繰り返しから構成されている。 付録は、式 (E) のように定義され、図の1個以上の繰 り返しから構成されている。この文書の構造を図3に示 している。

【0015】ここで、構造パターンとして、「図を持つ 章」を考える。この構造パターンは、次の条件の組合わ せである。

- 1. 文書部品Aは章である。
- 2. ある文書部品Bがあって、
- 2-1. 文書部品Bは図である。

2-2. 文書部品Bは文書構造中で文書部品Aに(直接 または間接に)従属する。

【0016】構造パターンマッチ処理部4は、図2のス テップ1において、文書テンプレートと構造パターンか ち次のように範囲の限定を行なう。まず、上述の式

(A) 乃至式 (E) から、文書に出現し得る部品の種類 は、論理根、章、文献リスト、付録、段落、章見出し、

【0011】図2は、構造パターンマッチ処理部におけ る探索処理の流れを説明するためのフローチャートであ る。まず、ステップ1において、テンプレート保持部2 に保持されているテンプレートと、構造パターン保持部 3に保持されている構造パターンから、文書の論理構造 のうちから、構造パターンマッチを行なう範囲を限定す る。

41.

【0012】次に、ステップ2において、論理構造保持 部1に保持されている文書の論理構造全体のうち、ステ ップ1で決定した限定された範囲についてのみ、構造バ ターンマッチを行なう。これにより、部分的に構造パタ ーンマッチを行なえばよいので、検索処理を高速化する ことができる。

【0013】構造パターンマッチ処理の具体例について 述べる。図3は、文書テンプレートの一例の説明図であ る。文書テンプレートの一例として、次のようなものを 考える。

文献名、図である。上述の条件1. 「文書部品Aは章で 20 ある。」を満たすのは、種類が章である部品のみであ る。また、上述の条件2-1.「文書部品Bは図であ る。」を満たすのは、種類が図である部品のみである。 さらに、上述の条件2-2、「文書部品Bは文書構造中 で文書部品Aに (直接または間接に) 従属する」を満た すのは、次の組合わせに限られる。

··· (A)

В

Λ 論理根 梗概 亩 論理根 文献リスト 論理报 論理恨 付録 梗慨 段落 論理根 段落 産見出し 章 育 段落 章見出し 論理恨 段落 論理报 文献リスト 文献名 文献名 論理报 図 付録 40 論理根

> 【0017】この組み合わせを求める方法としては、例 えば、推移的閉包の計算アルゴリズムとして広く知られ ているものを用いることができる。推移的閉包の計算で ルゴリズムについては、例えば、Alfred V.A ho, John E. Hoperoft, Jeffre y D. Ullman, "Data Structur es and Algorithms": Addiso n Wesley等に記載されている。

【0018】上述のように、文書部品への種類が章で、 文書部品Aに (直接または間接に) 従属する文書部品B であって、文書部品Bの種類が図であるものは存在しない。すなわち、上述の条件1., 2-1., 2-2を同時に満たす文書部品Aと文書部品Bの組み合わせはないことがわかる。従って、この例では、実際の文書の論理構造を調べることなく、構造パターンに適合する部分構造はないことがわかる。すなわち、構造パターンマッチを行なり必要はない。

【0019】文書テンプレート中の式 (C) が次のもので置き換えられたとしよう。

章::=章見出し (段落 | 図) +・・・(C') ここで、($A \mid B$) は、AまたはBの選択を示している。この式(C') は、章は1個の章見出しと、段落または図の1個以上の繰り返しからなることを表している。図4は、文書テンプレートの別の例の説明図である。図4では、ある1つの章が、1つの章見出しと1つの段落と1つの図を有する例を示している。

【0020】構造バターンマッチ処理部4は、図2のステップ1において、文書テンプレートと構造バターンから次のように範囲の限定を行なう。この例においても、上述の式(A),(B),(C'),(D),(E)から、文書に出現し得る部品の種類は、論理根、章、文献リスト、付録、段落、章見出し、文献名、図である。上述の条件1.「文書部品Aは章である。」を満たすのは、種類が章である部品のみである。また、上述の条件2-1.「文書部品Bは図である。」を満たすのは、種類が図である部品のみである。さらに、上述の条件2-2.「文書部品Bは文書構造中で文書部品Aに(直接または間接に)従属する」を満たすのは、次の組合わせに限られる。

文書部品A 文書部品B

論理根 梗概

論理根 章

論理根 文献リスト

論理根 付錄

梗概 段落

論理根 段落

章 章見出し

章 段落

愈 図

論理根 章見出し

論理根 段落

論理根 図

文献リスト 文献名

論理根 文献名

付録 図

論理根 図

【0021】上述のように、この例の場合には、文書部品Aの種類が章で、文書部品Aに(直接または間接に) 従属する文書部品Bであって、文書部品Bの種類が図で あることがあり得ることがわかる。また、この組み合わ せの結果から、章は梗機や文献リスト、付録の下位には ないことがわかる。従って、この例では梗概や文献リスト、 付録の中は調べる必要はなく、章の中の図を探せば 良いことがわかる。すなわち、図2のステップ2での構 10 造パターンマッチは、章の中に対してのみ行なえば良 く、梗概や文献リスト、付録の中に対しては行なわな い。

6

【0022】上述の2つの具体例のように、文書テンプレートを用いて構造パターンマッチを行なう範囲を限定してから、文書の論理構造を用いて構造パターンマッチを行なうので、マッチングを行なう範囲を限定し、あるいは、先の例のように、構造パターンマッチを行なわなくてよい場合も検出することができる。

【0023】これらの具体例は、簡単な構造バターンお 20 よび文書テンプレートについて示したが、もっと複雑な 構造パターンや文書テンプレートであっても適用可能で ある。例えば、構造パターンとして、「図を持つ章であ って、章題に『序文』という文字を有するもの」といっ た、より複雑な構造パターンについても処理可能であ る。

【0024】上述の文書テンプレートは、式により示したが、これは便宜上、式により表現しただけであり、他の表現方式を用いた文書テンプレートであっても、もちろんよい。

30 [0025]

【発明の効果】以上の説明から明らかなように、本発明によれば、文書テンプレートを用いて構造パターンマッチを行なう範囲を限定し、限定された範囲内で構造パターンマッチの処理を行なうので、構造パターンマッチの処理を効率良く、高速に行なうことができるという効果がある。

【図面の簡単な説明】

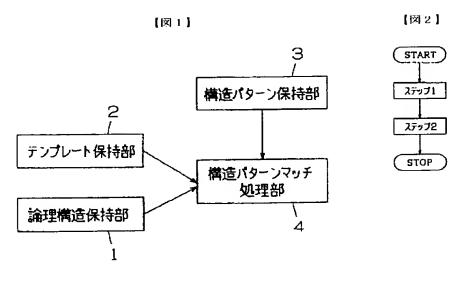
【図1】 本発明の文書処理装置の一実施例を示すプロック図である。

40 【図 2 】 構造バターンマッチ処理部における探索処理 の流れを説明するためのフローチャートである。

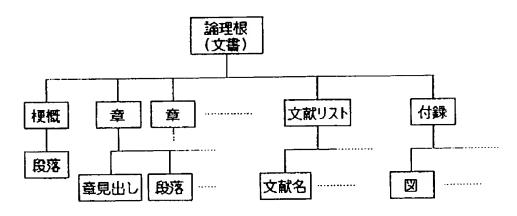
【図3】 文書テンプレートの一例の説明図である。

【図4】 文書テンプレートの別の例の説明図である。 【符号の説明】

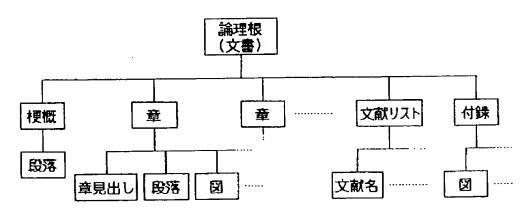
1 論理構造保持部、2 テンプレート保持部、3 構 造パターン保持部、4 構造パターンマッチ処理部。



【図3】



【図4】



フロントページの続き

(51) Int. Cl. ⁶

識別記号

庁内整理番号 9194--5L FΙ

G 0 6 F 15/40

技術表示簡所